

Sınır özniteliklerinin belirlenmesi ve adaptasyonu algoritması ve konsensüs karar verici yapılarda kullanımı

N. Gökhan KASAPOĞLU^{1*}, Okan K. ERSOY²

¹ İTÜ Elektronik ve Haberleşme Mühendisliği Bölümü, 34469 Maslak, İstanbul

² Purdue Üniversite, Elektrik ve Bilgisayar Mühendisliği, West Lafayette, IN 47907-1285, USA

Özet

Uzaktan algılama datalarının sınıflandırılmasında, genellikle, eğitim için kullanılan örneklerin sayısı sınırlıdır. Sınırlı sayıda eğitim kümesi elemanı, özellikle öznitelik vektörünün boyutunun büyük olduğu hiperspektral datalarda, parametrik sınıflayıcıların kullanımını kısıtlar. Bu yüzden, bu çalışmada, sınır özniteliklerinin belirlenmesi ve adaptasyonu algoritması (SÖBA) tanıtılmıştır. SÖBA algoritması iki bölümden oluşur. İlk aşamada sınır öznitelik vektörlerinin başlangıç değerleri uygun eğitim kümesi elemanlarından atanır. Bu atama işlemiyle yönetilebilir sayıda sınır özniteliği vektörü elde edilir. Daha sonra uygulanan adaptasyon işlemiyle, learning vector quantization' na (LVQ) benzer bir yapıda öğrenme süreci gerçekleştirilerek sınır özniteliklerinin, sonuç değerlerine ulaşması hedeflenir. Sınıflandırma sonuç sınır öznitelik vektörlerine olan en yakın 1 komşuluk (1-NN) kuralı uyarınca yapılır. Ek olarak, SÖBA algoritmasının sınır öznitelik vektörlerinin başlangıç değerlerine ve eğitim kümesi elemanlarının eğitimde kullanılma sırasına bağlı olarak her çalışmada kabul edilebilir derecede farklı sonuçlar vermesi, konsensüs yapılarda kullanılması için elverişli bir özelliktir. Böylece birçok defa çalıştırılan SÖBA kararlarının birleştirilmesiyle tek bir sınıflayıcının aldığı karardan çok daha doğru kararlar elde edilir.

Anahtar Kelimeler: Sınır karar yüzeyleri, hiperspektral data sınıflandırma, uzaktan algılama, konsensüs.

Border feature detection and adaptation algorithm and its usage in consensual decision maker structures

Abstract

In general there is limited number of training samples in remote sensing data classification. Use of parametric classification algorithms has some difficulties related to appropriate parameter estimation especially for hyperspectral data which has huge number of attributes (bands, features). In this study border feature detection and adaptation algorithm (BFDA) is introduced as a non-parametric classifier to overcome classification problem with limited number of training samples. The BFDA consist of two parts. In the first part of the algorithm, some selected training samples are assigned as initial reference vectors called border feature vectors. In the second part of the algorithm, border feature vectors are moved to the decision boundary by using an adaptation process which has some similarity with learning vector quantization algorithm (LVQ). At the end of the adaptation process, border feature vectors reach their final values. The method next uses the 1- Nearest Neighbor (1-NN) algorithm with these border feature vectors. In addition, the BFDA's performance is related to orders of the training vectors. Therefore, for every individual run of the BFDA, results are convenient to be combined by an appropriate consensual rule.

Keywords: Decision region borders, hyperspectral data classification, remote sensing, consensual.

*Yazışmaların yapılacağı yazar: N. Gökhan KASAPOĞLU. gokhank@itu.edu.tr; Tel: (212) 2853638.

Giriş

İstatistiksel sınıflandırmada genellikle datanın sahip olduğu istatistiksel dağılımın önceden belli bir istatistiksel dağılıma uyduğu varsayımı altında sınıflandırma işlemi yapılır. Bu varsayım genellikle eğitim için kullanılan örneklerin sayısı istatistiksel olarak doğru bir yargıya varmamız için yeterli olmayacağından iyi sonuçlar almamıza engel olabilir. Bu durum hiperspektral datalar için daha da önemli bir problem olarak karşımıza çıkmaktadır. AVIRIS gibi 220 band içeren sensörlerden elde edilen dataların sınıflandırılmasında herbir sınıf için en azından öznitelik uzayının boyutu kadar eğitim kümesi elemanına ihtiyaç olacaktır. Bu durum sağlansa bile sınıflandırmada nadir görülen (az sayıda örnek içeren) sınıfların doğru sınıflandırılması pek mümkün olmayacaktır. Bu açıdan sınıfların başlangıç olasılık kabullerine ihtiyaç duymayan, parametrik olmayan sınıflayıcılara ihtiyaç vardır. Bu amaçla bu çalışmada sınır özniteliklerinin belirlenmesi ve adaptasyonu algoritması tanıtılmıştır (SÖBA).

Burada tanıtılan SÖBA algoritması iki bölüme ayrılabilir. Algoritmanın ilk kısmı iteratif olarak sınır özniteliklerinin başlangıç değerlerini varolan eğitim kümesi elemanlarından seçer. Bu belirleme işleminde uygun seçilecek sınır elemanının sayısı daha sonra uygulanacak adaptasyon süreci için önemlidir. Gereğinden fazla sayıda seçilecek sınır elemanlarının sayısı adaptasyon başarımını azaltacaktır. Sınır elemanlarının başlangıç değerleri atandıktan sonra temelde learning vector quantization (LVQ) algoritmasına (Kohonen, 1990) benzeyen yeni bir adaptasyon yapısı kullanılır. Bu adaptasyon öznitelik uzayını daha önce belirlenmiş geometrik kısıtlar altında uygun şekilde bölütleyerek geleneksel yöntemlerle karşılaştırıldığında iyi başarımlar sağlar.

SÖBA algoritmasının sınır öznitelik elemanlarının başlangıç değerlerine ve eğitim kümesi elemanlarının eğitimde kullanılma sırasına bağlı olarak her çalışmada kabul edilebilir derecede farklı sonuçlar vermesi, konsensüs yapılar da kullanılması için elverişli bir özelliktir. Böylece birçok defa çalıştırılan SÖBA kararlarının birleştirilmesiyle tek bir sınıflayıcının aldığı karardan çok daha doğru kararlar elde edilir.

Sınır özniteliklerinin belirlenmesi ve adaptasyonu algoritması

Öznitelik uzayının eğitim kümesinden seçilmiş bazı referans vektörler yardımıyla bölütlenmesi doku tanıma problemlerinde sıkça kullanılan bir yöntemdir. Gereğinden fazla sayıda seçilen referans vektörlerinin sınıflandırmada kullanılması genelleme başarımını düşürebilir. Çoğu kez genelleme başarımını arttırmak için gereksiz vektörlerin belirlenmesi ve referans vektör olarak kullanılmaması gerekir. Gereksiz vektörlerin belirlenmesi için ise budama yöntemleri uygulanabilmektedir (Alpaydın, 1991).

Bu çalışmada sınır öznitelik belirlemesi adı verilen yeni bir referans vektör seçme yaklaşımı önerilmiştir. Bu yaklaşımda referans vektörlerin seçimi belirli geometrik kısıtlar altında yapılır. Destek vektör makinalarında (SVMs) olduğu gibi (Cristianini ve Taylor, 2000) seçilen referans vektörler öznitelik uzayında karar yüzeylerinin oluşmasını sağlar. Böylece seçilen referans vektörlerinin adaptasyon sonunda karar yüzeyine yakın olması sınıflandırma başarımını etkiler. Referans vektörlere eğitim kümesi içinden seçilen elemanların başlangıç değeri olarak atanması işlemine sınır özniteliklerinin belirlenmesi, referans vektörlere ise sınır öznitelik vektörleri adı verilir. Daha sonra uygulanan adaptasyon süreciyle sınır öznitelik vektörlerinin sonuç değerlerine ulaşarak öznitelik uzayını belirlenen geometrik kısıtlar altında düzgün bölütlemesi amaçlanır. Test için kullanılan örneklere, adaptasyon sonucunda elde edilen sonuç sınır öznitelik vektörlerine dayanan en yakın 1 komşuluk (1-NN) karar kuralı uygulanarak, en yakın 1 komşuluklarındaki sınır öznitelik vektörlerinin etiketleri atanır.

Sınır özniteliklerinin belirlenmesi

Sınır özniteliklerinin belirlenmesi algoritması aşağıda belirtilen özellikler düşünülerek geliştirilmiştir.

1. Sınır öznitelik vektörleri adapte edilebileceğinden mümkün olduğu kadar karar yüzeylerine yakın olacak şekilde seçilmelidirler.
2. Sınır öznitelik vektörleri seçimi otomatik olarak yapılmalı ve uygun sayıda başlangıç öznitelik vektörü seçilebilmelidir.
3. Herbir sınıfı öznitelik uzayında dengeli biçimde temsil etmek için herbir sınıf uygun sayıda sınır öznitelik vektörüne sahip olmalıdır.

Sınır öznitelik vektörlerinin başlangıç değerlerinin seçimi için sınıf merkezleri kullanılır. Belirli bir sınıf merkezi o sınıf ortalamasına en yakın vektör olarak tanımlanır. Sınıf ortalaması yerine sınıf merkezinin kullanılması, eğitim örneklerinin öznitelik uzayında içbükey şekilde dağılması durumu için önlemdir.

Etiketleriyle birlikte bir eğitim kümesi $\{(\bar{x}_1, y_1), (\bar{x}_2, y_2), \dots, (\bar{x}_n, y_n)\}$ şeklinde gösterilirse ve buradaki n adet eğitim kümesi vektörlerinin N boyutlu olduğu ve etiketlerinin $y_i \in \{1, 2, \dots, m\}$ şeklinde değiştiği kabul edilirse, m toplam sınıf sayısı olmak üzere sınıf ortalamaları aşağıdaki denklemde gösterildiği gibi hesaplanabilir:

$$\bar{m}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \bar{x}_j, \{\bar{x}_j | y_j = i, i = 1, \dots, m\} \quad (1)$$

Bu denklemde n_i i . sınıf için toplam örnek sayısıdır. i . sınıf için sınıf merkezi \bar{c}_i aşağıdaki denklemde gösterildiği gibi hesaplanabilir:

$$\bar{c}_i = \bar{x}_k, \left\{ \begin{array}{l} k = \arg \min \{D_j\} \\ (1 \leq i \leq m), (1 \leq j \leq n) \\ D_j(\bar{m}_i, \bar{x}_j) = \|\bar{m}_i - \bar{x}_j\| = \sum_{d=1}^N (m_i(d) - x_j(d))^2, \{\bar{x}_j | y_j = i\} \end{array} \right\} \quad (2)$$

Sınır özniteliklerinin belirlenmesi algoritmasında herbir sınıf için uygun eğitim kümesi elemanları sınır öznitelik vektörlerinin başlangıç değeri olarak sınıf merkezleri yardımıyla seçilir. Sınır öznitelik vektörlerinin başlangıç değerleri $\mathbf{B}^{i=0}$, sınıf merkezleri \mathbf{B}_0 ve herbir sınıf için sınıf merkezleri yardımıyla seçilen örnekler kümesinin, $\mathbf{B}_i, i = 1 \dots m$, birleşimidir.

$$\mathbf{B}^0 = \bigcup_{0 \leq i \leq m} \mathbf{B}_i \quad (3)$$

Sınır öznitelik vektörü $\bar{b}_j, j \leq m$ için $\bar{b}_j = \bar{c}_j$ olarak tanımlanır. Böylece b toplam belirlenen sınır öznitelik vektörü sayısı, sınıf merkezleri sayısı $m_0 = m$ ve sınıf merkezleri yardımıyla herbir sınıf için belirlenen sınır öznitelik vektörleri sayısının, $m_i, i = 1, \dots, m$, toplamı olur.

$$b = \sum_{i=0}^m m_i = m + \sum_{i=1}^m m_i \quad (4)$$

Sınır öznitelik belirleme algoritmasındaki amacımız öznitelik uzayını uygun sayıda sınır öznitelik vektörüyle temsil etmektir. Bu amaçla her bir sınıf için başlangıçta yalnızca sınıf merkezlerini referans vektörler olarak kabul eden bir belirleme algoritması uygulanır.

$$\mathbf{R}_i(t=0) = \mathbf{B}_0 \cup \mathbf{B}_i = \mathbf{B}_0 \quad (5)$$

Hangi sınıfa ait sınır öznitelikleri belirleniyorsa o sınıfın tüm elemanları sadece bir kez olmak üzere rastgele seçilerek belirleme algoritmasında denir. Seçilen eğitim kümesi örneğinin etiketi, bu eğitim kümesi örneğine en yakın bir komşuluğunda olan referans kümesi elemanının etiketinden farklı ise, kendi sınıfına ait yeni sınır öznitelik elemanı olarak \mathbf{B}_i kümesine ART1 algoritmasına benzer şekilde atanır (Carpenter ve Grosberg, 1987).

Adaptasyon işlemi

Adaptasyon işleminde yarışmacı öğrenme prensipleri aşağıda açıklandığı şekilde uygulanır: Sınır öznitelik vektörlerinin başlangıç değeri, \mathbf{B}^0 , sınır öznitelik vektörleri ve onların ortalamaları arasındaki mesafeyi maksimum yapmak, farklı etiketli komşu sınır öznitelik vektörleri arasındaki marjini arttırmak için adaptif olarak güncellenir. Burada (3) numaralı denklemlerle tanımlanan sınır öznitelik elemanlarının ortalaması aşağıdaki denklemlerle belirlenir:

$$\bar{m}_i = \frac{1}{m_i + 1} \sum_{j=1}^b \bar{b}_j, \{\bar{b}_j | y_j = i, i = 1, \dots, m\} \quad (6)$$

$$\mathbf{M}^0 = \{(\bar{m}_1, y_1), (\bar{m}_2, y_2), \dots, (\bar{m}_m, y_m)\} \quad (7)$$

Normal olarak sınır öznitelik vektörlerinin ortalaması sonuç karar sürecinde kullanılmaz. Algoritmanın geometrik kısıtlarından ötürü sınır öznitelik vektörlerinin ortalamalarının kullanılması gereksizdir. Yani sonuç karar sürecinde, test örneklerinin sınıflandırılmasında kullanılıp kullanılmaması başarıyı etkilemez. Eğitim sırasında ise sınır öznitelik vektörlerinin ortalaması yeni sınır özniteliliğine ihtiyaç olup olmadığını gösteren kontrol vektörleri olarak düşünülebilir. Eğitim sırasında sınır öznitelik vektörlerinin ortalaması hatalı karara neden oluyorsa sınırda bir açık olduğu düşünülerek eğitim sırasında hatalı karar verilen eğitim kümesi örneği sınırdaki açığı kapatmak için yeni sınır öznitelik vektörü olarak sınır öznitelik vektörleri kümesine eklenir. Sınır öznitelik vektörlerinin adaptasyonunda, sınır öznitelik vektörlerinin ortalaması da sınır öznitelik vektörlerinin değişimine bağlı olarak güncellenir.

Adaptasyon için uygulanan strateji aşağıdaki gibi açıklanabilir: hatalı karara neden olan en yakın sınır öznitelik vektörü $\bar{b}_w(t)$ hatalı karar verilen eğitim kümesi örneğinden uzaklaşmalı, seçilen eğitim kümesi örneğiyle aynı etikete sahip sınır öznitelik elemanı $\bar{b}_i(t)$ ise, seçilen eğitim elemanına yaklaşmalıdır. Learning vector quantization (LVQ) algoritmasına benzeyen bir adaptasyon yapısı kullanılmaktadır.

Sınır özniteliklerinin belirlenmesi ve adaptasyonu algoritması ve konsensüs karar verici yapılarda kullanımı

\bar{x}_j 'nin y_j etiketine sahip bir eğitim kümesi örneği olduğunu varsayalım. y_{b_w} etiketli sınır öznitelik vektörü $\bar{b}_w(t)$ 'nin \bar{x}_j 'ye en yakın sınır öznitelik vektörü olduğu kabul edelim. Bu durumda eğer $y_j \neq y_{b_w}$ ise adaptasyon aşağıda gösterildiği şekilde uygulanır:

$$\bar{b}_w(t+1) = \bar{b}_w(t) - \eta(t) \cdot (\bar{x}_j - \bar{b}_w(t)) \quad (8)$$

$$\bar{m}_{y_{b_w}}(t+1) = \left(m_{y_{b_w}} \cdot \bar{m}_{y_{b_w}}(t) - \eta(t) \cdot (\bar{x}_j - \bar{b}_w(t)) \right) / m_{y_{b_w}} \quad (9)$$

Eğer y_{b_l} etiketli $\bar{b}_l(t)$, eğitim için seçilen ve hatalı karar verilen \bar{x}_j ile aynı etikete sahip, $y_j = y_{b_l}$, sınır öznitelik vektörleri içinde en yakında olan sınır öznitelik vektörü ise, adaptasyon işlemi aşağıda ifadelerle belirlendiği şekliyle uygulanır:

$$\bar{b}_l(t+1) = \bar{b}_l(t) + \eta(t) \cdot (\bar{x}_j - \bar{b}_l(t)) \quad (10)$$

$$\bar{m}_{y_{b_l}}(t+1) = \left(m_{y_{b_l}} \cdot \bar{m}_{y_{b_l}}(t) + \eta(t) \cdot (\bar{x}_j - \bar{b}_l(t)) \right) / m_{y_{b_l}} \quad (11)$$

Adaptasyon ifadelerindeki $\eta(t)$ zamanla azalan bir fonksiyon olup öğrenme hızı olarak adlandırılır. $\eta(t)$ için iyi bir seçim aşağıdaki ifade de verilmiştir.

$$\eta(t) = \eta_0 e^{-t/\tau} \quad (12)$$

Adaptasyon sırasında t' gibi önceden belirlenmiş bir iterasyon sayısına ulaşıldıktan sonra, \mathbf{M}^t ve \mathbf{B}^t kümelerinin birleşimi referans düğümler olarak giriş eğitim vektörlerinin sınıflandırılması için kullanılır. Eğer y_j etiketli seçilmiş \bar{x}_j eğitim kümesi örneği için en yakın referans düğüm y_{m_w} etiketli bir sınır özniteliklerinin ortalaması kümesi elemanı, $\bar{m}_w(t > t')$, ise ve $y_j \neq y_{m_w}$ durumunda hatalı karar verilen eğitim örneği \bar{x}_j , yeni sınır öznitelik vektörü olarak eklenir.

$$\mathbf{B}^{t+1} = \mathbf{B}^t \cup \{(\bar{x}_j, y_j)\}, \quad (t > t') \quad (13)$$

Bu durumda ilgili ortalama vektörü de aşağıdaki şekilde güncellenecektir.

$$\bar{m}_{y_j}(t+1) = \left(m_{y_j}(t) \cdot \bar{m}_{y_j}(t) + \bar{x}_j \right) / (m_{y_j}(t) + 1) \quad (14)$$

(14) ifadesinde $m_{y_j}(t)$, t iterasyonu anında y_j etiketli sınır öznitelik vektörlerinin sayısıdır. Bundan dolayı $m_{y_j}(t+1)$ eklenen yeni sınır öznitelik vektöründen sonra y_j etiketli sınır öznitelik vektörleri sayısını gösterir.

Test kümesi örneklerinin sınıflandırılması, seçilen örneğin adaptasyon sonucunda elde edilen sınır öznitelik vektörlerine olan en yakın bir komşuluğu dikkate alınarak yapılır.

SÖBA sonuçlarının konsensüs karar verici yapılarda kullanılması

SÖBA algoritmasının sonucu hem sınır özniteliklerinin belirlenmesi hem de adaptasyonu sırasında kullanılan eğitim kümesi örneklerinin seçilme sırasıyla yakından ilgilidir. SÖBA'nın farklı her koşturulmasında rastgele seçilen eğitim kümesi örnekleri nedeniyle, öznitelik uzayı yaklaşık benzer başarımlar sağlayarak farklı şekilde bölümlenebilmektedir. Daha önce sıkça kullanılan hem parametrik hem de parametrik olmayan sınıflayıcıların kararlarının birleştirilmesiyle karşılaştırıldığında sistem yaklaşımı açısından SÖBA'nın farklı sonuçlarının birleştirilmesi tatminkar sonuçlar vermektedir.


Konsensüs karar verici kuralları ise Maksimum kuralı, Minimum kuralı, Ortalama kuralı ve çoğunluk oylaması kuralı olabilmektedir (Benediktsson vd.,1997; Jimenez vd., 1999). Bunlara ek olarak en küçük kareler analizi yöntemiyle de birleştirilecek kararlar için optimal ağırlık katsayıları belirlenebilmektedir (Lee ve Ersoy, 2006). Hatta yapay sinir ağları ve SÖBA algoritmasında kararların birleştirilmesi için kullanılabilir.

Bu çalışmada genellikle eğitim kümesi başarımları %95'i geçtiği için herbir sınıf için verilen kararın güvenilirliğine bağlı bir güvenilirlik faktörünün yerine, çoğunluk oylaması kuralı kullanılmıştır. Sonuçlarda görülen konsensüs-SÖBA neticeleri, SÖBA'nın 10 kez çalıştırılması ve elde edilen 10 farklı sonucun herbir piksel için karar verirken çoğunluk oylaması yöntemi kullanılarak elde edilmiştir. Eğitim başarımının yüksek olduğu durumlarda çoğunluk oylaması yönteminin daha iyi sonuçlar verdiği görülmüştür.

DeneySEL Sonuçlar

Kullanılan data ve kurulan deneyler

Deneylerde, kuzeybatı Indiana'dan 1992 haziran ayında toplanan AVIRIS datası kullanılmıştır (Langrebe ve Biehl, 1992). Şekil 1'de gösterilen bu data çok iyi bilinen bir test datasıdır ve sıklıkla hiperspektral dataların sınıflandırılma algoritmalarını test etmek için kullanılmaktadır.



Şekil 1. AVIRIS datası a) 50, 27 ve 17. bandlar için görüntü. b) 17 sınıf için referans yer verisi.

Kullanılan data setinin boyutları 145x145 piksel olup, iki farklı sınıf ve iki farklı spektral band kombinasyonu için deneyler kurulmuştur. 17 sınıflık eğitim kümesi örnekleri (değişik sınıfların bir karışımı olan bazı örnekler karışım tip sınıf örnekleri olarak ele alınmıştır) ve 9 sınıflık örnekler (istatistiksel olarak anlamlı 9 sınıf ele alınmıştır), 9 spektral band (multispektral dataları temsil etmesi için) ve 190 spektral band (30 spektral band orijinal band sayısı 220 olan AVIRIS datasından

atmosferik etkilerden ötürü çıkarılarak kullanılmamıştır) için oluşturulmuştur. Tablo 1' de eğitim ve test için kullanılan 4 farklı data setinde herbir sınıfa ait örnek sayıları gösterilmiştir.

Tablo 1. Deneylerde kullanılan eğitim ve test kümelerindeki örnek sayıları.

17-SINIF Data Kümesi-1/2 (9 / 190 BAND)			9- SINIF Data Kümesi 3/4 (9/190 BAND)		
Sınıf	Eğitim	Test	Sınıf	Eğitim	Test
ω_1	719	2627	-	-	-
ω_2	16	39	-	-	-
ω_3	201	720	ω_1	288	846
ω_4	157	498	ω_2	200	448
ω_5	63	117	-	-	-
ω_6	112	265	ω_3	197	281
ω_7	207	409	ω_4	200	442
ω_8	12	24	-	-	-
ω_9	196	374	ω_5	209	357
ω_{10}	14	16	-	-	-
ω_{11}	255	519	ω_6	193	597
ω_{12}	545	1302	ω_7	493	1757
ω_{13}	128	310	ω_8	199	286
ω_{14}	102	132	-	-	-
ω_{15}	546	870	ω_9	258	795
ω_{16}	109	229	-	-	-
ω_{17}	21	44	-	-	-
Toplam	3403	8495	Toplam	2237	5809
Tüm data	21065		Tüm data	9345	

Karşılaştırma

SÖBA algoritmasının başarımı, destek vektör makinalarının (Melgani ve Bruzzone, 2004) yanında maximum likelihood, Fisher linear likelihood, correlation ve matched filtering gibi istatistiksel sınıflayıcılar ve parametrik olmayan k-NN algoritması da dahil olmak üzere karşılaştırmalı olarak verilmiştir. Tablo 2' de ortalama eğitim, test başarımları, Tablo 1' de açıklanan 4 farklı data kümesi için, kappa istatistiği de dahil olmak üzere gösterilmiştir. Kappa istatistiği genel sınıflandırma başarımının yanında her bir sınıf için verilen kararların güvenilirliğinde bir göstergesidir. Öyle ki, azınlık sınıflarının korunup korunmadığı hakkında bize bilgi verir. Tablo 2' de data kümesi 4 için maximum likelihood sınıflayıcı sonuçlarından anlaşılacağı gibi kappa istatistiğinin test başarımından çok düşük olduğu durumda sadece çok eğitim örneği içeren sınıfların korunduğu anlaşılabilir. Data kümesleri 1 ve 2 için sınıflandırma probleminin karmaşıklığı data kümeleri 3 ve 4' göre nispeten fazladır. Ayrıca data kümesi 1' de karışım tipli bir sınıf da mevcuttur. Data kümeleri 1 ve 2 için az sayıda örnek içeren azınlık sınıfları da bulunmaktadır. Data kümeleri 2 ve 4 için ise istatistiksel olarak anlamlı sınıfların ele alındığı söylenebilir. SÖBA algoritmasının başarımı geleneksel istatistiksel yöntemlere nazaran tüm data kümeleri için oldukça iyidir. Özellikle azınlık sınıflarını da içeren karmaşık problemlerde, data kümeleri 1 ve 2' de olduğu gibi, SÖBA algoritması destek vektör makinaları da dahil olmak üzere en iyi sonuçları vermektedir. Problemin karmaşıklığı azaldığında, destek vektör makinalarının (RBF-SVM) başarımının yükseldiği söylenebilir. Elde edilen sonuçlar göstermiştir ki bu çalışmada tanıtılan SÖBA algoritması hem multispektral hem de hiperspektral datalar için sınıfların istatistiğine bağlı kalmaksızın tutarlı sonuçlar üretmektedir. Konsensüs-SÖBA için ise verilen sonuçlar, SÖBA' nın 10 kez çalıştırılması sonucu elde edilen sonuçların çoğunluk oylaması yöntemiyle birleştirilmesiyle elde edilmiştir. Konsensüs-SÖBA algoritması için sonuçlar tüm data kümeleri için oldukça tatminkardır.

Tablo 2. Ortalama eğitim test başarımları ve kappa istatistiği.

Data Kümesi	Metod	Eğitim		Test	
		Başarım %	κ	Başarım %	κ
1	Maximum likelihood	84.83	0.82	67.56	0.63
	Fisher linear likelihood	63.7	0.59	47.3	0.42
	Correlation	48.4	0.43	37.2	0.31
	Matched Filter	32.8	0.24	36.1	0.29
	k-NN	89.01	0.87	68.06	0.63
	RBF SVM	77.13	0.74	67.72	0.64
	SÖBA	93.57	0.89	71.16	0.67
	Konsensüs-SÖBA	95.06	0.93	73.79	0.69
2	k-NN	90.71	0.89	70.01	0.65
	RBF SVM	87.54	0.86	72.49	0.69
	SÖBA	99.79	0.99	74.27	0.71
	Konsensüs-SÖBA	100	1	76.89	0.73
3	Maximum likelihood	87.07	0.85	77.86	0.74
	k-NN	93.69	0.92	83.04	0.80
	RBF SVM	92.59	0.91	78.86	0.75
	SÖBA	96.69	0.96	84.64	0.81
	Konsensüs-SÖBA	99.37	0.99	87.03	0.84
4	Maximum likelihood	100	1	67.00	0.57
	Fisher linear likelihood	91.3	0.90	81.8	0.78
	Correlation	45.4	0.39	47.7	0.40
	Matched filter	78.1	0.75	72.6	0.67
	k-NN	95.08	0.94	84.31	0.81
	RBF SVM	100	1	91.18	0.90
	SÖBA	100	1	89.75	0.88
	Konsensüs-SÖBA	100	1	91.65	0.90

Kaynaklar

- Alpaydin, E., (1991) GAL: networks that grow when they learn and shrink when they forget, Technical Report 91-032, International Computer Science Institute, Berkeley, CA.
- Benediktsson, J.A., Sveinsson, J.R., Ersoy, O.K. ve Swain, P.H., (1997). Parallel consensual neural networks, *IEEE Trans. Geosci. Remote sensing*, **8**, 1, 54-64.
- Carpenter, G.A. ve Grosberg, S., (1987). A massively parallel architecture for a self organizing neural pattern recognition machine, *Computer Vision, Graphics, and Image Processing*, **37**, 54-115.
- Chee, H.M. ve Ersoy, O.K., A (2005). statistical self-organizing learning system for remote sensing classification, *IEEE Trans. Geosci. Remote Sensing*, **432**, 1890-1900.
- Cristianini, N. ve Taylor, J.S., (2000). *Support Vector Machines*, Cambridge University Press.
- Jimenez, L.O., Morell, A.M. ve Creus, A., (1999). Classification of hyperdimensional data based feature and decision fusion approaches using projection pursuit, majority voting, and neural networks, *IEEE Trans.*
- Joachims, T., (1999). *Making large-Scale SVM Learning Practical. Advances in Kernel Methods* in Schölkopf, B., Burges, C., ve Smola, A., eds, *Support Vector Learning*, MIT-Press.
- Kohonen, T., (1990). The self-organizing map, *Proceedings of the IEEE*, **78**, 9.
- Langrebe D. ve Biehl, L., Multispec and AVIRIS NW Indiana's Indian Pines 1992 data set. <http://www.ece.purdue.edu/~biehl/MultiSpec/index.html>
- Lee, J. ve Ersoy, O., (2006). Consensual and hierarchical classification of remotely sensed multispectral images, Proceedings, IGARRS 2006, Denver, USA.
- Melgani, F. ve Bruzzone, L., (2004). Classification of hyperspectral remote sensing images with support vector machines, *IEEE Trans. Geosci. Remote Sensing*, **42**, 1778-1790.